

无蜂窝大规模 MIMO 网络下基于联邦学习的用户接入策略及能耗优化

姚媛媛^{1,2}, 刘忆秋^{1,2}, 黄赛³, 潘春雨^{1,2}, 李学华^{1,2}, 袁昕⁴

(1. 北京信息科技大学信息与通信系统信息产业部重点实验室, 北京 100101; 2. 北京信息科技大学现代测控技术教育部重点实验室, 北京 100101; 3. 北京邮电大学泛网无线通信教育部重点实验室, 北京 100876; 4. 悉尼科技大学电气与数据工程学院, 悉尼 NSW 2007)

摘要: 针对无蜂窝大规模多输入多输出 (CF-mMIMO) 网络中用户如何选择接入点的问题, 提出了一种基于信道排序的较差用户优先接入策略。首先, 用户进行信道感知后对其信道质量和稳定性进行评估和排序, 用户按照信道状态信息的顺序依次选择合适的接入点; 其次, 考虑到用户的能耗与数据安全等问题, 采用联邦学习框架以增强用户的数据隐私安全, 并提出一种基于能耗优化的交替优化变量算法, 对多维变量进行优化, 使系统总能耗最小化。仿真结果表明, 相较于传统的大规模 MIMO 中用户为中心的接入策略, 所提接入策略可使用户平均上行可达速率提升 20%, 信道较差用户的上行速率可提升 2 倍; 在能耗优化方面, 优化后的总能耗可降低 50% 以上。

关键词: 无蜂窝大规模 MIMO; 用户接入; 智能感知; AP 选择; 能耗优化

中图分类号: TN929.5

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2023188

Federated learning-based user access strategy and energy consumption optimization in cell-free massive MIMO network

YAO Yuanyuan^{1,2}, LIU Yiqiu^{1,2}, HUANG Sai³, PAN Chunyu^{1,2}, LI Xuehua^{1,2}, YUAN Xin⁴

1. Key Laboratory of Information and Communication Systems, Ministry of Information Industry, Beijing Information Science and Technology University, Beijing 100101, China

2. Key Laboratory of Modern Measurement & Control Technology, Ministry of Education, Beijing Information Science and Technology University Beijing 100101, China

3. Key Laboratory of Universal Wireless Communications, Ministry of Education, Beijing University of Posts and Telecommunications, Beijing 100876, China

4. School of Electrical and Data Engineering, University of Technology Sydney, Sydney NSW 2007, Australia

Abstract: To solve the problem that how users choose access points in cell-free massive multiple-input multiple-output (CF-mMIMO) network, a prioritized access strategy for poorer users based on channel coefficient ranking was proposed. First, users were evaluated and ranked for their channel quality and stability after channel sensing, and suitable access points were selected in sequence according to the order of the channel state information. Second, considering issues such as users' energy consumption and data security, a federal learning framework was used to enhance user's data privacy and security. Meanwhile, an alternating optimization variables algorithm based on energy consumption optimization was proposed to optimize the multi-dimensional variables, for the purpose of minimizing the total energy consumption of the system. Simulation results show that compared with the traditional user-centric in massive MIMO, the proposed access strategy can improve the average uplink reachable rate of users by 20%, and the uplink rate of users with poor channels can be double improved; in terms of energy consumption optimization, the total energy consumption can be reduced by much more than 50% after optimization.

Keywords: cell-free massive MIMO, user access, intelligent sensing, AP selection, energy consumption optimization

收稿日期: 2023-05-05; 修回日期: 2023-08-07

通信作者: 黄赛, huangsai@bupt.edu.cn

基金项目: 国家自然科学基金资助项目 (No.62301059); 北京市属高等学校优秀青年人才培养计划基金资助项目 (No.BPHR202203228); 泛网无线通信教育部重点实验室 (BUPT) 基金资助项目 (No.KFKT-2020105); 北京市自然科学基金-海淀联合基金资助项目 (No.L212026, No.L222004)

Foundation Items: The National Natural Science Foundation of China (No.62301059), The Project of Cultivation for Young Top-Motch Talents of Beijing Municipal Institutions (No.BPHR202203228), The Key Laboratory of Universal Wireless Communications (BUPT), Ministry of Education (No.KFKT-2020105), Beijing Natural Science Foundation-Haidian Original Innovation Joint Fund (No.L212026, No.L222004)

0 引言

随着移动通信技术和物联网的发展, 各类无线终端用户和物联网设备的数量爆发式增加, 由此产生的移动数据流量也呈指数级增长。要实现如此海量的通信需求, 从用户接入到用户间的相互通信, 都需要相应的技术支持。现有的大规模多输入多输出 (mMIMO, massive multiple-input multiple-output) 技术是 5G 网络的关键技术之一, 其在发射端和接收端均配有多根天线, 运用多址技术和复用技术, 实现多用户之间的高效通信。随着用户数量的增多, 为提高蜂窝小区的容量, 小区划分从宏蜂窝演变为微蜂窝, 多天线技术以及超密集组网技术也应运而生。同时, 由于低频段频谱资源越发紧缺, 6G 正逐渐迈向太赫兹通信。而太赫兹通信虽然速率高, 但覆盖距离短、基站数目多, 随着蜂窝小区划分面积的不断缩小, 小区之间的相互干扰以及用户因移动而频繁越区的问题日益严重, 再加上集中式系统中天线规模的增大使物理上实现困难, 进而导致用户的通信速率并不能得到持续提升。为了突破这些瓶颈问题, 迎合未来网络的发展需求, 国内外学者开始尝试对传统蜂窝网络架构进行变革和创新。美国纽约大学的 Marzetta 教授和瑞典林雪平大学的 Larsson 教授于 2017 年共同提出了无蜂窝大规模 MIMO (CF-mMIMO, cell-free massive MIMO) 技术^[1]。在无蜂窝大规模 MIMO 网络中, 不再部署具备大量 MIMO 阵列的大型基站, 而是通过海量的接入点 (AP, access point) 来为用户提供服务^[2]。所有 AP 通过回程链路连接到中央处理器 (CPU), 用户与 AP 之间通过无线链路连接。在时分多址模式下, 所有用户使用相同的频段进行通信^[3]。

由于消除了小区与小区之间的限制, 因此, 理论上用户可以选择区域内的任意 AP 为其服务, 同理, 每个 AP 也可以为区域内的任何用户提供服务。然而, 在现实中, 用户选择 AP 时要考虑多种因素。首先, AP 能够支持的终端数量有限; 其次, 若用户选择与自己距离较远的 AP, 考虑到路径损耗和阴影衰落等因素, 用户与该 AP 之间较差的信道质量会严重影响通信性能, 此时选择该 AP 的收益不大。因此, 对用户来说, 如何合理地选择最佳 AP 是应当重点考虑的问题, 合理的感知接入策略是保障用户通信和系统性能的重要前提。Ngo 等^[2]提出了一种用户按照随机顺序选择 AP 的方法, 仿真结果显示, 该方法的用户平

均吞吐量过低, 系统性能并不理想。Buzzi 和 Dandrea^[4-5]提出了一种以用户为中心 (UC, user-centric) 的 AP 分配方案, 每个 AP 计算自己与所有用户之间的信道系数, 并只服务那些具有最大信道系数的用户, 这样虽然使 AP 将资源集中在最优用户上, 但无法保证信道质量较差的用户也能够被分配到合适的 AP。Chen 等^[6]提出了一种基于竞争机制的 AP 分配算法, 对于某一 AP, 信道系数较大的用户将在竞争中胜出, 取得该 AP 的使用权, 同时该算法维护了一个竞争失败的用户名单, 并在竞争结束后为这些用户分配剩下的 AP, 然而竞争失败的用户很有可能与分配到的 AP 之间信道质量较差, 通信质量依旧不够理想。Ngo 等^[7]研究发现, 回程链路的功率消耗会显著影响系统能量效率, 对此提出了 2 种简单的 AP 分配方案, 即基于大尺度衰落和基于接收功率的 AP 选择方案, 旨在降低回程链路的功耗。Dao 等^[8]提出了一种基于信道增益的 AP 选择方案, 通过推导每个用户的频谱效率 (SE, spectral efficiency) 并以系统总 SE 最大化为目标, 来确定用户与哪个 AP 进行连接。Biswas 等^[9]利用机器学习算法来为无蜂窝大规模 MIMO 系统中的用户选择 AP, 提出了一种基于集群的 AP 选择算法, 并在选择时优先为用户选择具有较高频谱效率的 AP。

上述研究工作从不同角度出发, 均对用户与 AP 之间的选择方案进行了研究, 然而, 文献[4-6]均基于信道质量较强用户优先选择的准则, 文献[7-9]则以实现最优频谱效率或能量效率为目标, 并未优先考虑提升用户的通信速率。对于信道质量较差的用户, 上述方法并不能很好地保证其通信质量。因此, 本文从弱者优先的角度出发, 提出了一种基于信道排序的较差用户优先 (CPCS, channel poor user priority based on channel sorting) 接入策略。根据文献[7-8]的 AP 选择方案, 利用用户与 AP 之间的信道系数作为衡量用户信道质量的标准, 即信道系数的高低代表了信道质量的好坏。以此为依据, 本文首先计算每个用户与其他 AP 之间的信道系数, 以信道系数的高低和方差作为依据, 来衡量用户的信道状态好坏和稳定性, 并以此作为衡量用户信道综合质量的 2 个指标, 对所有用户计算其指标后按升序排序, 以确保将信道质量较差的用户排到前面; 其次, 所有用户按照排序依次选择合适的 AP 为其提供服务, 由此实现信道质量较差的用户优先完成接入, 保证了信道条件较差用户的通信质量, 同时提升了系统的平均通信速率。

此外,随着移动用户数量的不断增长,传统的机器学习面临数据传输时延较高、用户隐私安全无法保证的问题,新兴的联邦学习(FL, federated learning)算法可有效解决这些问题^[10-11]。联邦学习利用了边缘计算的思想,即处于边缘节点的用户也可处理数据,在 FL 中,用户只需将本地学习得到的模型参数上传到 CPU,而不需要共享整个训练数据,就可以协同执行学习任务。目前,联邦学习前景十分广阔。

然而,在无线网络上实现 FL,用户必须通过无线链路传输它们的本地训练模型参数,FL 的性能可能会因有限的无线资源(如网络带宽和用户功率)而受到影响,因此,有必要考虑 FL 在无线网络中的资源调度及分配问题。Xu 等^[12]研究了 FL 在无线网络中的带宽分配问题,提出了一种分布式带宽分配算法来优化 FL 的整体性能,且同时兼顾了资源分配的公平性和用户隐私的安全性;Behmandpoor 等^[13]利用局部深度神经网络来实现 FL 在无线网络中的资源分配问题,包括对用户的功率分配及最大化用户数据传输速率。然而,用户的能量受限也是部署 FL 架构的一个关键挑战,若用户在通信过程中能耗过高,很可能导致电量不足,从而严重影响其通信性能,因此,有必要对用户的能耗问题进行优化。Vu 等^[14]提出了一种可支持 FL 运行的 CF-mMIMO 网络架构,并以训练时间最小化为目标来优化 FL 的性能,但并未考虑用户的能量消耗问题;Yang 等^[15]研究了 FL 在无线网络中的计算资源分配和节能传输等问题,但未考虑 CF-mMIMO 场景下的计算资源调度问题。因此,本文研究了 CF-mMIMO 场景下的联邦学习框架,建立了该框架下的用户总能耗表达式,提出了一种基于能耗优化的交替优化变量(AIEO, alternating iterations with the goal of energy consumption optimization)算法,对多维变量进行优化,使系统总能耗降到最低。

本文的主要研究工作及创新点总结如下。

1) 建立了基于联邦学习的无蜂窝大规模 MIMO 系统架构,根据用户与 AP 之间的信道条件,提出了 CPCS 接入策略,该策略综合考虑每个用户的信道质量和稳定性,对所有用户的信道质量进行排序,令信道较差的用户优先选择最佳 AP。

2) 建立联邦学习框架下的系统能耗分析模型,综合考虑传输时间、功率、学习精度等因素,构建能效最小化的目标函数表达式,提出 AIEO 算法,并对用户总能耗进行优化。

3) 将所提接入策略与传统的无蜂窝大规模 MIMO 中用户接入策略进行对比,仿真结果表明,所提 CPCS 接入策略与能耗优化算法在用户整体上行可达速率方面有显著提升,且优化前后的对比显示总能耗得到显著降低。

1 系统模型

考虑一个典型的 CF-mMIMO 场景,AP 和用户均随机分布在同一区域内,且 AP 和用户均为单天线,用户可选择单个 AP 进行接入,每个 AP 仅为一个用户提供服务。分布式 AP 通过回程链路连接到 CPU,用户则通过无线链路与 AP 进行连接。假设该区域内共有 M 个 AP 和 K 个用户,AP 的集合表示为 $\mathcal{M}=\{1, 2, \dots, M\}$,用户集合表示为 $\mathcal{K}=\{1, 2, \dots, K\}$ 。当进行联邦学习时,用户利用其本地数据进行本地模型训练,并将计算结果经无线链路上传至为其服务的 AP,AP 再将结果通过回程链路发送至 CPU,CPU 汇集所有用户的计算结果以计算全局模型更新,并将新的计算结果经回程链路发送给 AP 至各用户,以使用户进一步完成本地模型的更新。当模型结果达到一定的学习精度时,该迭代过程终止。无蜂窝大规模 MIMO 系统模型如图 1 所示。




图 1 无蜂窝大规模 MIMO 系统模型

1.1 信道模型

在该模型场景下,用户 k 与第 m 个 AP 之间的信道可表示为

$$g_{k,m} = \sqrt{\beta_{k,m}} h_{k,m} \quad (1)$$

其中, $\beta_{k,m}$ 和 $h_{k,m}$ 分别表示第 m 个 AP 与用户 k 之间的大尺度衰落系数及小尺度衰落系数。 $h_{k,m}$ 服从分布 $\mathcal{CN}(0,1)$ ^[5]。大尺度衰落系数可以表示为

$\beta_{k,m} = 10^{\frac{PL_{k,m}}{10}} 10^{\frac{\sigma_{sh} z_{k,m}}{10}}$ [5], 其中, $PL_{k,m}$ 表示从用户 k

到第 m 个 AP 的路径损耗(单位为 dB), $10^{\frac{\sigma_{sh} z_{k,m}}{10}}$ 为阴影衰落, 标准差为 σ_{sh} ; $z_{k,m}$ 为阴影系数。路径损耗模型表示为^[16]

$$PL_{k,m} = \begin{cases} -L - 35 \lg d_{k,m}, & d_{k,m} > d_1 \\ -L - 10 \lg(d_1^{1.5} d_{k,m}^2), & d_0 < d_{k,m} < d_1 \\ -L - 10 \lg(d_1^{1.5} d_0^2), & d_{k,m} < d_0 \end{cases} \quad (2)$$

其中, $d_{k,m}$ 表示第 k 个用户与第 m 个 AP 之间的距离。 L 满足

$$L = 46.3 + 33.9 \lg(f) - 13.82 \lg(A_{AP}) - [1.1 \lg(f) - 0.7] A_{UE} + 1.56 \lg(f) - 0.8 \quad (3)$$

其中, f 为载波频率, 单位为 MHz; A_{AP} 和 A_{UE} 分别为 AP 和用户的天线高度。由于在实际场景中, 距离相近的用户和 AP 可能被共同的障碍物包围, 因此, 阴影系数 $z_{k,m}$ 是相关的, 可表示为^[17]

$$z_{k,m} = \sqrt{\delta} a_m + \sqrt{1 - \delta} b_k \quad (4)$$

其中, $m=1, \dots, M, k=1, \dots, K$, a_m 和 b_k 均服从分布 $\mathcal{N}(0,1)$ 且为独立随机变量, 参数 δ 满足 $0 \leq \delta \leq 1$ 。

a_m 和 b_k 的协方差函数分别为

$$E[a_m, a_{m'}] = 2 \frac{d_{AP}(m, m')}{d_{decorr}} \quad (5-1)$$

$$E[b_k, b_{k'}] = 2 \frac{d_{UE}(k, k')}{d_{decorr}} \quad (5-2)$$

其中, $d_{AP}(m, m')$ 为第 m 个 AP 与第 m' 个 AP 之间的欧氏距离; $d_{UE}(k, k')$ 为第 k 个用户与第 k' 个用户之间的距离; 参数 d_{decorr} 为取决于环境的去相关距离, 取值范围为 $20 \sim 200$ m^[4]。

1.2 用户上行数据传输模型

由于采用时分多址通信模式, 所有用户使用相同的频段进行通信。如图 2 所示, 用户与 AP 间的信道感知可分为以下 3 个阶段: 上行信道感知、下行信令确认、上行数据传输。在上行信道感知阶段, 用户向 AP 发送导频数据, 以便 AP 进行信道感知; 在下行信令确认阶段, AP 执行信道感知、信道匹配波束成形, 并在下行链路上发送信令, 以使用户确认; 在上行数据传输阶段, 用户向 AP 发送数据。由于用户只在上行链路发送数据, 考虑到后续的能耗分析, 从用户角度出

发, 本文主要讨论上行链路的信道感知和上行数据传输可达速率。

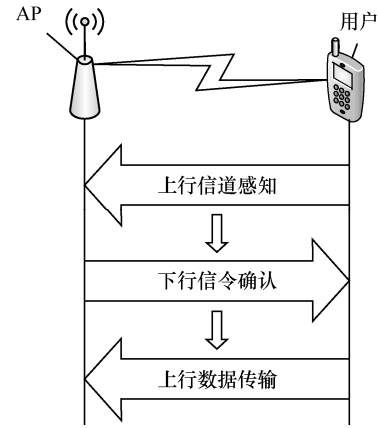


图 2 信道感知的 3 个阶段

1.2.1 上行信道感知

采用导频匹配法来完成上行信道感知。令 τ_c 为信道相干时间的长度, τ_p 为上行训练阶段的时间长度, 其中 $\tau_c > \tau_p$ 。令 ϕ_k 表示第 k 个用户发送的 τ_p 维导频序列, 且 $\|\phi_k\|^2 = 1$ 。在训练阶段, 第 m 个 AP 接收到的信号可表示为

$$y_m = \sum_{k=1}^K \sqrt{p_k} g_{k,m} \phi_k + w_m \quad (6)$$

其中, p_k 为第 k 个用户在训练阶段的传输功率; w_m 为 τ_p 维列向量, 表示热噪声影响和小区外干扰, 其分量为独立同分布的随机变量, 且服从分布 $\mathcal{CN}(0, \sigma_w^2)$ 。利用 AP 的接收向量, 可以对 $g_{k,m}$ 进行信道感知, 表示为

$$\hat{g}_{k,m} = \frac{1}{\sqrt{p_k}} \phi_k^H y_m \quad (7)$$

其中, $(\cdot)^H$ 表示共轭转置。

1.2.2 上行数据传输

由于用户可以自行选择区域内的 AP 为自己服务, 令 $Z(k)$ 为用户 k 所选择的为其提供服务的 AP 集合, 则用户 k 的上行信噪比为

$$SINR_k = \frac{p_k^{UL} \left| \sum_{m \in Z(k)} \hat{g}_{k,m}^* g_{k,m} \right|^2}{\sigma_w^2 \sum_{m \in Z(k)} |g_{k,m}|^2 + \sum_{j=1, j \neq k}^K p_j^{UL} \left| \sum_{m \in Z(k)} \hat{g}_{k,m}^* g_{j,m} \right|^2} \quad (8)$$

用户 k 的上行数据传输速率为

$$\mathcal{R}_k^{\text{UL}} = W \log(1 + \text{SINR}_k) \quad (9)$$

其中, W 为带宽。在时分多址模式下, 所有用户使用相同的带宽来进行数据传输。

2 基于信道排序的较差用户优先接入策略

本节阐述所提出的基于信道排序的较差用户优先接入策略。如前文所述, 第 k 个用户与第 m 个 AP 之间的信道可表示为 $g_{k,m}$, 将此系数作为评判信道质量的依据^[1,7], $g_{k,m}$ 越大, 表明用户 k 与 AP _{m} 之间的信道质量越高。此外, 考虑到用户与不同 AP 之间的信道质量有所差异, 而方差是用来衡量一组数据波动大小的量, 方差越大, 表明这组数据偏离平均数越大, 即波动越大, 数据越不稳定; 方差越小, 表明这组数据分布比较集中, 各数据偏离平均数越小, 即波动越小, 数据越稳定。因此, 为综合评判用户与 AP 间的信道质量, 用方差来描述用户信道质量的稳定性。具体来说, 对于每个用户, 首先计算其与每个 AP 之间的信道系数之和 $\sum_{m=1}^M g_{k,m}$ 以

及方差, 并对所有用户的信道系数及方差进行升序排序, 由此每个用户得到 2 个排序序号 a_k 和 b_k , 以此作为信道质量评估的 2 个指标。所提 CPCS 接入策略流程如图 3 所示, 步骤如算法 1 所示, 首先对所有用户的信道质量进行评估排序, 随后再按照该顺序依次选择 AP。

算法 1 基于信道系数排序的较差用户优先接入策略

- 1) 初始化数组 $\text{AP}[] = \text{zeros}(1, K)$, $\text{Rank}[]$, $\text{Result}[]$;
- 2) for $k=1$ to K :
- 3) for $k=1$ to K :
- 4) 计算信道系数和 $\sum_{m=1}^M g_{k,m}$;
- 5) 计算方差;
- 6) end for;
- 7) 对信道系数和进行升序排序, 返回用户 k 的位次 a_k ;
- 8) 对方差进行升序排序, 返回用户 k 的位次 b_k ;
- 9) 令 $E_k = a_k - \lambda b_k$;
- 10) 将用户 k 与所有 AP 间的信道系数降序排序, 并返回 AP 序号, 将其记录在数组 $\text{UE}_k[]$ 中;

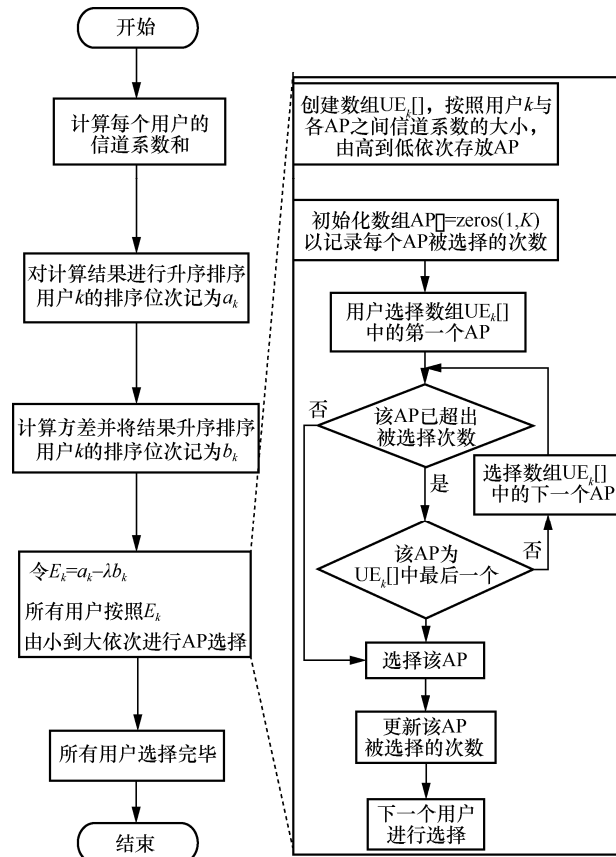


图 3 CPCS 接入策略流程

- 11) end for;
- 12) 对所有 E_k 进行升序排序, 并将对应的用户序号记录在数组 $\text{Rank}[]$ 中, 用户按照数组 $\text{Rank}[]$ 所记录的顺序依次选择 AP;
- 13) for $i=1$ to K
- 14) 选择数组 $\text{UE}_k[]$ 中的第一个 AP;
- 15) while 当前所选 AP 被选择的次数已超出最大值
- 16) if 当前 AP 是数组 $\text{UE}_k[]$ 中的最后一个
- 17) break
- 18) else
- 19) 选择数组 $\text{UE}_k[]$ 中的下一个 AP;
- 20) end if
- 21) 选择当前 AP
- 22) end while
- 23) 在数组 $\text{AP}[]$ 中更新该 AP 被选择的次数;
- 24) 将选择结果记录在数组 $\text{Result}[]$ 中;
- 25) end for
- 26) 输出选择结果 $\text{Result}[]$

在算法 1 中, λ 为排序权值且满足 $\lambda \geq \frac{1}{N}$ 。对用户 k 来说, 在轮到自身选择 AP 进行接入时, 总是按照数组 $UE_k[]$ 中存放的 AP 顺序来选择, 即优先选择与自身之间信道系数更大的 AP, 以求获得更好的通信性能。然而, 若用户当前所选择的 AP 被其他用户所选择的次数已超过限制, 且此 AP 也是数组 $UE_k[]$ 中的最后一个, 则用户只能选择该 AP。此时该用户被视为接入失败, 因为该 AP 实际上已经不能为其提供服务。然而, 在 CF-mMIMO 系统中, AP 数量往往均等于甚至远多于用户数量, 此类接入失败的情况发生的概率较小。针对 AP 数量不足导致用户接入失败的情况, 本文将在第 4 节进行讨论。

值得注意的是, 算法 1 的复杂度取决于用户数量 K 及 AP 选择情况。由于数组 $UE_k[]$ 按照用户 k 与各 AP 间信道系数的大小从高到低依次存放 AP, 因此, 对于每个用户来说, 其数组 $UE_k[]$ 中的第一个 AP 为其最佳 AP。在最理想的情况下, 每个用户的最佳 AP 各不相同, 在选择时仅需进行一次判断比较便可选择其最佳 AP, 此时算法 1 的时间复杂度仅与用户数量 K 有关, 为 $\mathcal{O}(K)$; 在最复杂的情况下, 所有用户的数组 $UE_k[]$ 所存放的 AP 顺序相同, 第一个进行选择的用户完成选择后, 第二个选择的用户经 2 次判断比较后选择 $UE_k[]$ 中的第二个 AP, 依此类推, 最后一个用户选择时需判断比较 K 次, 所有用户完成选择共需判断比较 $0.5K(K+1)$ 次, 此时算法 1 的时间复杂度为 $\mathcal{O}(0.5K(K+1))$ 。由此可见, 算法 1 时间复杂度的下界和上界分别为 $\mathcal{O}(K)$ 和 $\mathcal{O}(0.5K(K+1))$ 。

3 基于能耗优化的交替优化变量算法

本节阐述用户能耗模型及所提 AIEO 算法。首先, 分析了 CF-mMIMO 网络下的 FL 框架; 其次, 构建了用户能耗优化的目标函数及约束条件, 并提出 AIEO 算法进行求解。

3.1 基于联邦学习框架的模型设计

要考虑 FL 框架下的用户能耗问题, 首先要明确用户如何在无线网络上实现 FL。在 CF-mMIMO 场景中, CPU 相当于 FL 框架中的中心服务器, 用户相当于 FL 框架中的终端。用户进行本地计算后, 只需上传模型结果, 而不需要上传原始数据, CPU 聚合这些本地模型以更新全

局训练模型, 再将更新后的参数下发给用户, 以进一步协助其进行本地计算。由此, 用户承担了一部分的计算任务, 减轻了中心服务器的负担, 降低了数据传输时延, 同时, 数据隐私也得到了更好的保护, 因为原始数据不需要通过无线网络传输。

在 CF-mMIMO 网络中部署 FL, 假设用户数据规模为 D_k , 即每个用户都有自己的本地数据集 $\mathcal{D}_k = \{1, \dots, D_k\}$ 。所有用户的总数据集样本大小为 $D_T = \sum_{k \in \mathcal{K}} D_k$, 全局数据样本为 $\mathcal{D} = \{1, \dots, D_T\}$ 。在一般的监督学习中, 数据样本 $i \in \mathcal{D}$ 被定义为输入-输出对 $\{\mathbf{x}_i \in \mathbb{R}^d, y_i\}$ 。对于用户 k 来说, 其总损失函数为

$$F_k(\boldsymbol{\omega}, \mathbf{x}_i, y_i) = \frac{1}{D_k} \sum_{i=1}^{D_k} f(\boldsymbol{\omega}, \mathbf{x}_{ki}, y_{ki}) \quad (10)$$

其中, $\boldsymbol{\omega}$ 为模型参数, $f(\boldsymbol{\omega}, \mathbf{x}_{ki}, y_{ki})$ 为单个数据样本的损失函数。在对底层模型进行训练后, 可以部署 FL 模型。FL 训练问题可表示为^[18-19]

$$\min_{\boldsymbol{\omega}} F(\boldsymbol{\omega}) \triangleq \sum_{k=1}^K \frac{D_k}{D} F_k(\boldsymbol{\omega}, \mathbf{x}_i, y_i) = \frac{1}{D} \sum_{k=1}^K \sum_{i=1}^{D_k} f(\boldsymbol{\omega}, \mathbf{x}_{ki}, y_{ki}) \quad (11)$$

其中, $D = \sum_{k=1}^K D_k$ 表示所有用户的总数据样本量。

要解决上述问题, 可考虑随机梯度下降法和分布式牛顿算法等^[15]。在 FL 过程中, 每个用户同时进行本地迭代计算, 达到本地计算精度要求后将计算结果上传至 CPU, CPU 将所有用户的计算结果聚合后进行全局模型更新, 并将更新后的模型参数发送给用户, 进行下一轮迭代, 直至达到全局计算精度。

由于在 CF-mMIMO 网络中, 与用户直接相连的是为其服务的 AP 而非 CPU, 因此用户上传本地计算结果时, 需先经过无线链路上传至 AP, 再由 AP 经回程链路上传至 CPU。在此过程中, 回程链路承担了连接主干网和接入网的功能, CPU 既可以通过回程链路向用户下发计算任务, 减轻自身计算负担, 又可以经由回程链路及时收到来自用户的计算结果。

3.2 能耗模型

每个用户在进行本地计算和结果上传时均会

产生相应的能耗。

3.2.1 本地计算能耗

设用户 k 的计算能力为 f_k , 其与 CPU 的转速有关。则用户 k 进行本地数据处理所需时间为^[20]

$$s_k = \frac{I_k C_k D_k}{f_k} \quad (12)$$

其中, C_k 为用户 k 计算一个数据样本所需要的 CPU 周期数, I_k 为用户 k 进行本地迭代的次数。由此可得用户 k 进行本地计算所消耗的能量为^[21]

$$E_k^C = \varphi I_k C_k D_k f_k^2 \quad (13)$$

其中, φ 为与用户芯片结构有关的有效电容系数^[22]。

3.2.2 传输能耗

用户 k 在完成本地计算后, 需将计算结果经由 AP 上传至 CPU。由于每个用户的数据规模相同, 因此可设其需要上传的数据规模均为 d 。设传输时间为 t_k , 用户 k 的平均发射功率为 p_k , 则用户 k 将本地计算结果上传至 AP 所消耗的能量为

$$E_k^T = t_k p_k \quad (14)$$

为了保证在传输时间 t_k 内完成全部数据上传, 需满足 $t_k p_k \geq d$ 。

综上所述, 参与 FL 的所有用户的总能耗为

$$E = I_g \sum_{k=1}^K (E_k^C + E_k^T) \quad (15)$$

其中, I_g 为 FL 算法的全局迭代次数。当参与 FL 的用户采用梯度下降算法和随机梯度下降算法等优化算法时, 若用户的本地学习精度均为 ε , 全局学习精度为 θ , 则学习精度和迭代次数的关系可表示为^[23-24]

$$I_k = \gamma \text{lb} \frac{1}{\varepsilon} \quad (16)$$

$$I_g = \frac{\zeta \text{lb} \frac{1}{\theta}}{1 - \varepsilon} \quad (17)$$

其中, $\gamma, \zeta > 0$, 其值取决于用户本地数据集的大小和结构。

3.2.3 能耗优化模型

综上所述, 为使用户总能耗最小化, 可以将该优化问题用以下目标函数来描述

$$\begin{aligned} & \min_{t, p, \varepsilon} I_g \sum_{k=1}^K (E_k^C + E_k^T) \\ \text{s.t. C1: } & \frac{\zeta \text{lb} \frac{1}{\theta}}{1 - \varepsilon} \left(\frac{\gamma \text{lb} \frac{1}{\varepsilon} C_k D_k}{f_k} + t_k \right) \leq T \\ \text{C2: } & t_k \mathcal{R}_k^{\text{UL}} \geq d, \forall k \in \mathcal{K} \\ \text{C3: } & 0 \leq p_k \leq p_k^{\text{max}}, \forall k \in \mathcal{K} \\ \text{C4: } & 0 \leq \varepsilon \leq 1 \\ \text{C5: } & t_k \geq 0, \forall k \in \mathcal{K} \end{aligned} \quad (18)$$

其中, $\mathbf{t} = [t_1, t_2, \dots, t_k]^T$, $\mathbf{p} = [p_1, p_2, \dots, p_k]^T$ 。 t_k 为用户 k 将计算结果上传至 AP 的所需时间, p_k^{max} 为用户 k 的最大平均发射功率。约束条件 C1 表示忽略 AP 将数据上传至 CPU 的时间, 所有用户进行本地计算和结果上传的总时间不能超过 FL 算法的最大完成时间 T 。约束条件 C2 为对用户传输数据量的约束, 即所有用户需保证在规定时间内完成所有数据上传。约束条件 C3 为所有用户的最大平均发射功率限制。约束条件 C4 为用户进行本地计算时的本地精度约束。约束条件 C5 表明上传时间 t_k 应为非负值。

为解决式(18), 本文利用所提出的 AIEO 算法来求得目标函数最小值。该算法分为两步。首先, 固定变量 \mathbf{p} , 优化变量 \mathbf{t} 和 ε 。根据式(18)中的约束条件 C2, 可以得到 \mathbf{t} 的最优解为

$$t_k^0 = \frac{d}{\mathcal{R}_k^{\text{UL}}} \quad (19)$$

此时, 式(18)转化为解决如下问题

$$\begin{aligned} & \min_{\varepsilon} \frac{c_1 \text{lb} \frac{1}{\varepsilon} + c_2}{1 - \varepsilon} \\ \text{s.t. C1: } & 0 \leq \varepsilon \leq 1 \\ \text{C2: } & t_k^0 \leq \frac{(1 - \varepsilon)T}{\zeta \text{lb} \frac{1}{\theta}} + \frac{\gamma \text{lb} \frac{1}{\varepsilon} C_k D_k}{f_k} \end{aligned} \quad (20)$$

其中, $c_1 = \zeta \text{lb} \frac{1}{\theta} \sum_{k=1}^K \varphi C_k D_k f_k^2$, $c_2 = \zeta \text{lb} \frac{1}{\theta} \sum_{k=1}^K t_k^0 p_k$ 。

式(20)中的约束条件 C2 表明, 所求得的最优解 t_k^0 应满足式(18)中约束条件 C1 关于 FL 算法总完成时间的要求。由式(20)求得该函数的二阶导数大于 0, 可知式(20)为凸函数, 且区间有限, 因此可采用三分法来求区间内的最优值 ε_k^0 。

然后, 固定变量 \mathbf{t} 和 ε , 优化变量 \mathbf{p} 。此时, 式(18)

可简化为

$$\begin{aligned} & \min_p \frac{\zeta \text{lb} \frac{1}{\theta}}{1-\varepsilon} \sum_{k=1}^K t_k p_k \\ \text{s.t. } & \text{C1: } t_k \mathcal{R}_k^{\text{UL}} \geq d, \forall k \in \mathcal{K} \\ & \text{C2: } 0 \leq p_k \leq p_k^{\max}, \forall k \in \mathcal{K} \end{aligned} \quad (21)$$

由式(21)可知, 目标函数为关于 p_k 的单调递增函数, 因此最优解 p_k^0 即满足上述约束条件的最小值。具体步骤如算法 2 所示。

算法 2 基于能耗优化的交替优化变量算法

1) 初始化 $t=t^{(0)}$ 、 $\varepsilon = \varepsilon^{(0)}$ 、 $p=p^{(0)}$, 迭代次数 $n=0$, 设置算法精度 ρ

2) repeat

3) 计算总能耗 $E^{(n)}$

4) 固定 $p^{(n)}$

5) 优化 $t^{(n+1)} = \frac{d}{\mathcal{R}_k^{\text{UL}}}$

6) 根据式(20), 利用三分法优化 $\varepsilon^{(n+1)}$

7) 输入 left=0, right=1

8) while right - left > 10^{-4}

9) midl = $\frac{2\text{left} + \text{right}}{3}$

10) midr = $\frac{\text{left} + 2\text{right}}{3}$

11) $f(x) = \frac{c_1 \text{lb} \frac{1}{x} + c_2}{1-x}$

12) if $f(\text{midl}) > f(\text{midr})$

13) left=midl;

14) else

15) right=midr;

16) end if

17) end while

18) $\varepsilon^{(n+1)} = \text{midl}$

19) 固定 $t^{(n+1)}$ 和 $\varepsilon^{(n+1)}$

20) 根据式(21)计算优化后的 $p^{(n+1)}$

21) 根据 $p^{(n+1)}$ 、 $t^{(n+1)}$ 和 $\varepsilon^{(n+1)}$, 计算优化后的用户总能耗 $E^{(n+1)}$

22) set $n=n+1$;

23) until $\frac{|1 - E^{(n+1)}|}{|E^{(n)}|} < \rho$

24) 输出 $E^{(n+1)}$, n

在算法 2 中, 其时间复杂度与算法迭代次数有关。在每次迭代中, 由于步骤 6)~步骤 17)使用了三分搜索算法, 因此, 在该算法的一次迭代中, 时间复杂度约为 $\mathcal{O}(\log n)$ 。假设算法 2 达到其算法精度而收敛时的迭代次数为 J_{AIEO} , 则算法 2 的整体时间复杂度为 $\mathcal{O}(J_{\text{AIEO}}(\log n))$ 。

4 仿真结果

本节利用 MATLAB 进行仿真验证, 假设 AP 位置固定, 均匀分布在一个半径为 100 m 的圆形区域内, CPU 位于区域中心位置, 即圆心处, 用户位置则通过随机撒点来进行模拟并确定。在仿真中, AP 数量总是大于或等于用户数量。假设最终每个用户选择一个 AP 为自己服务, 每个 AP 也仅为一个用户提供服务, 并分别考虑了不同 AP 数量的几种场景。仿真参数如表 1 所示。

表 1 仿真参数

参数	数值
路径损耗因子 $L^{[25]}$ / dB	140.7
带宽 W/ MHz	20
路径损耗模型参数 d_0 / m	10
路径损耗模型参数 d_1 / m	50
载波频率 f / GHz	1.9
计算所需 CPU 周期数 C_k	2×10^4
芯片有效电容系数 ϕ	10^{-28}
用户最大发射功率 p_k^{\max} / dBm	40
用户本地数据规模 d / (kbit·s ⁻¹)	28.1
全局学习精度 θ	10^{-3}
用户数据规模 D_k	500
AIEO 算法精度 P	10^{-2}
用户数量 UE	10
仿真圆形区域半径 R / m	100

用户数量为 10 时, 在不同 AP 数量和用户发射功率的场景下, 权值 λ 对用户平均上行速率的影响如图 4 所示。从图 4 可以看到, 当 AP 数量相同时, 适当增大用户发射功率可提高用户平均上行速率, 而当权值逐渐增加时, 所有场景下的用户平均上行速率都得到了提升, 当发射功率为 0 时, 在 AP=10 和 AP=20 下, 用户平均上行速率分别在权值 $\lambda=0.2$ 和 $\lambda=0.8$ 时得到了提升, 并分别由 17.87 Mbit/s 和 24.63 Mbit/s 增长至 21.79 Mbit/s 和 30.65 Mbit/s, 分别提升了 21.9%及 24.2%, 当发射功率为-30 dBm

时同理最大可提升 27.1%。不同的是速率得到提升时的权值不同。这是因为当 AP 数量增多时，用户彼此间的信道系数和差距减小，这时信道质量的稳定性，即方差成为评估用户信道质量的主要因素，权值越高，信道评估时方差所占比重越大，信道质量较差的用户在最终评估中所处位次越靠前，越能够优先选择 AP，这也体现了本文策略的“弱者优先”机制。此外，还可看出，在相同的用户发射功率下，AP 数量越多，用户平均上行速率越高，这是因为用户在选择 AP 时是按照用户与 AP 间的信道系数从高到低择优选取，AP 数量越多，出现信道系数较高的 AP 的概率越大，从而使用户获得越高的上行速率。




图 4 权值对用户平均上行速率的影响

如图 5 所示，为验证信道最差用户的速率提升情况，本文计算了不同场景下信道最差用户的上行速率，并将所提 CPCS 接入策略与 UC 接入策略^[4-5]进行了对比（权值 λ 均取 0.8），其中用户数量为 10。由图 5 可以看出，在相同的用户发射功率下，对于信道最差用户，使用 CPCS 接入策略可获得更高的上行速率，且 2 种接入策略下的速率差距随着用户发射功率的增加先逐渐增大，然后保持不变。这是因为对于信道最差的用户来说，2 种接入策略下所选择的 AP 不同，进而根据式(8)和式(9)，使用本文所提 CPCS 接入策略可获得比 UC 接入策略更高的上行信噪比，且信噪比的差距随上行发射功率的增加而增大，而当上行发射功率增加到一定值时，噪声影响可忽略不计，信噪比趋于恒定，故此时用户上行速率也趋于恒定。在本节仿真中，可以看出，当上行发射功率在 20 dBm 附近时，用户上行速率趋于恒定。

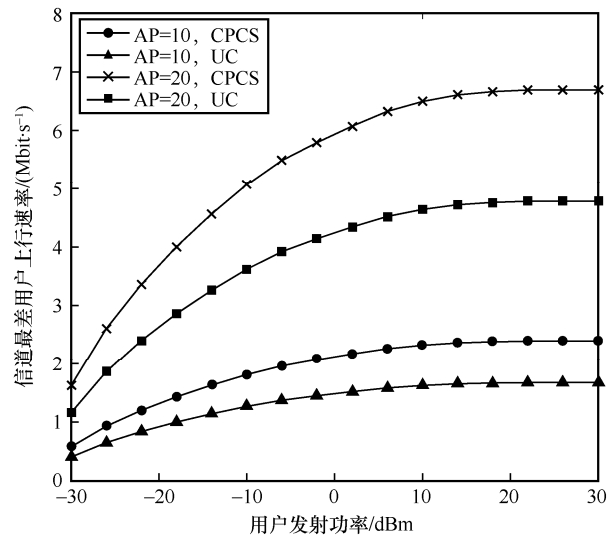


图 5 信道最差用户上行速率对比

图 6 考虑了用户数量为 10 且 AP 数量少于用户数量的接入情况(用户发射功率均为 20 dBm, CPCS 接入策略中权值 λ 取 0.5)。由图 6 可得，与 AP 数量充足的图 5 相比，2 种接入策略的用户平均上行速率均受到了影响，出现大幅降低，而随着 AP 数量的增长又逐渐得到提升。这是因为当 AP 数量少于用户数量时，部分用户并未实现接入，上行速率为 0，从而影响了用户平均上行速率。从图 6 还可以看出，使用 CPCS 接入策略可以使信道最差用户获得更高的上行速率。这也说明在 AP 数量不足的情况下，使用 CPCS 接入策略可以更好地保障信道最差用户的通信性能。




图 6 AP 数量不足时的接入情况分析

图 7 显示了 2 种场景下信道最差用户的能量效率对比。仿真结果显示，在相同的用户上行发射功率下，所提 CPCS 接入策略的用户能量效率总是高于作为

对比的 UC 接入策略。值得注意的是，尽管所提接入策略可以获得更高的能量效率，但在图 7 中所有场景下，2 种接入策略的用户能量效率均随着用户发射功率的增大而逐渐降低，后趋于恒定。这是因为当功率增大到一定值时，用户速率趋于恒定，而通信中的能效定义为有效信息传输速率与信号发射功率的比值，由图 5 中的分析可得，此时继续增大用户的发射功率，用户上行速率也不再提升，故能效也不会增加，这也说明了优化用户发射功率的必要性。

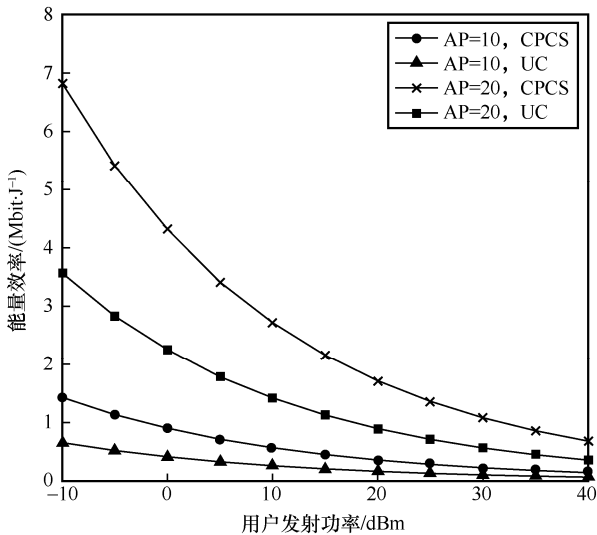


图 7 信道最差用户能量效率对比

图 8 显示了在用户数量为 10 且不同 AP 数量的场景下，用户总传输能耗随发射功率的变化，由图 4 分析可知，当 AP 数量增多时，用户更有可能获得更高的上行速率，从而在相同的发射功率下，因传输耗时减少而取得更少的传输能耗。而由图 8 可得，在不同场景下，总传输能耗均随用户发射功率的增加而增大，为优化用户发射功率，应取同时满足 $t_k \mathcal{R}_k^{UL} \geq d$ 和 $0 \leq p_k \leq p_k^{\max}$ 这 2 个约束条件的最小值。

图 9 为在 AP 数量为 10，且用户数量为 10 场景下，变量优化前后用户总能耗的对比。由图 9 可知，用户总能耗随着用户发射功率的增加而逐渐增大，且发射功率相同时，随着变量 t 和 ϵ 被优化，用户的计算能耗和传输能耗均得到了降低，故总能耗随之减小，当用户以最大发射功率（即 40 dBm）工作时，最高可节省 67.4% 的能耗。

图 10 为对 AIEO 算法的收敛性分析，用户数量为 10。从图 10 可以看出，算法开始运行后，平均迭代 3 次后算法收敛，且在不同 AP 数量的场景下，相较于变量优化前，能耗均减少了 50% 以上。




图 8 用户总传输能耗随发射功率的影响




图 9 优化前后总能耗对比




图 10 交替优化算法收敛性分析

5 结束语

本文研究了无蜂窝大规模 MIMO 网络中的用户接入及能耗优化问题。对于用户接入时的 AP 选

择问题,提出了一种基于信道排序的信道较差用户优先的接入策略,通过综合评估用户的信道质量来确定用户进行 AP 选择的顺序;对于能耗优化问题,建立了联邦学习框架下的系统能耗分析模型,并构建能耗最小化的目标函数表达式,提出了一种基于能耗优化的交替优化变量算法。仿真结果表明,与传统的 AP 选择算法相比,所提接入策略可提升 20% 左右的用户整体上行可达速率,且信道较差用户的上行速率可实现两倍提升。在能耗优化方面,优化后的总能耗可降低 50% 以上。综上所述,本文所提出的接入策略和能耗优化算法对于研究 CF-mMIMO 场景下的用户接入及通信性能提升具有指导意义,对于构建未来智能化社会网络架构具有一定的参考价值。然而,本文的研究重点均集中在上行信道,尚未考虑下行链路的一些情况,如对 AP 进行功率分配、能效分析等,以及如何将深度强化学习算法与本文的研究工作相结合,更好地实现无蜂窝大规模 MIMO 网络中的用户接入及通信资源分配,提升系统性能。这也将成为下一步的研究方向。

参考文献:

- [1] 李文风. 去蜂窝大规模 MIMO 系统中导频分配及 AP 选择技术研究[D]. 北京: 北京邮电大学, 2021.
LI W F. Research on pilot assignment and AP selection technology in cell-free massive MIMO system[D]. Beijing: Beijing University of Posts and Telecommunications, 2021.
- [2] NGO H Q, ASHIKHMEN A, YANG H, et al. Cell-free massive MIMO versus small cells[J]. IEEE Transactions on Wireless Communications, 2017, 16(3): 1834-1850.
- [3] NGO H Q, ASHIKHMEN A, YANG H, et al. Cell-free massive MIMO: uniformly great service for everyone[C]//Proceedings of IEEE 16th International Workshop on Signal Processing Advances in Wireless Communications. Piscataway: IEEE Press, 2015: 201-205.
- [4] BUZZI S, DANDREA C. User-centric communications versus cell-free massive MIMO for 5G cellular networks[C]//Proceedings of 21th International ITG Workshop on Smart Antennas. Berlin: VDE, 2017: 187-192.
- [5] BUZZI S, DANDREA C. Cell-free massive MIMO: user-centric approach[J]. IEEE Wireless Communications Letters, 2017, 6(6): 706-709.
- [6] CHEN S F, ZHANG J Y, BJÖRNSON E, et al. Structured massive access for scalable cell-free massive MIMO systems[J]. IEEE Journal on Selected Areas in Communications, 2021, 39(4): 1086-1100.
- [7] NGO H Q, TRAN L N, DUONG T Q, et al. On the total energy efficiency of cell-free massive MIMO[J]. IEEE Transactions on Green Communications and Networking, 2018, 2(1): 25-39.
- [8] DAO H T, KIM S. Effective channel gain-based access point selection in cell-free massive MIMO systems[J]. IEEE Access, 2020, 8: 108127-108132.
- [9] BISWAS S, VIJAYAKUMAR P. AP selection in cell-free massive MIMO system using machine learning algorithm[C]//Proceedings of 2021 Sixth International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET). Piscataway: IEEE Press, 2021: 158-161.
- [10] MOZAFFARI M, SAAD W, BENNIS M, et al. Mobile unmanned aerial vehicles (UAVs) for energy-efficient Internet of things communications[J]. IEEE Transactions on Wireless Communications, 2017, 16(11): 7574-7589.
- [11] LI T, SAHU A K, TALWALKAR A, et al. Federated learning: challenges, methods, and future directions[J]. IEEE Signal Processing Magazine, 2020, 37(3): 50-60.
- [12] XU J, WANG H Q, CHEN L X. Bandwidth allocation for multiple federated learning services in wireless edge networks[J]. IEEE Transactions on Wireless Communications, 2022, 21(4): 2534-2546.
- [13] BEHMANDPOOR P, PATRINOS P, MOONEN M. Federated learning based resource allocation for wireless communication networks[C]//Proceedings of 30th European Signal Processing Conference (EUSIPCO). Piscataway: IEEE Press, 2022: 1656-1660.
- [14] VU T T, NGO D T, TRAN N H, et al. Cell-free massive MIMO for wireless federated learning[J]. IEEE Transactions on Wireless Communications, 2020, 19(10): 6377-6392.
- [15] YANG Z H, CHEN M Z, SAAD W, et al. Energy efficient federated learning over wireless communication networks[J]. IEEE Transactions on Wireless Communications, 2021, 20(3): 1935-1949.
- [16] TANG A, SUN J X, GONG K. Mobile propagation loss with a low base station antenna for NLoS street microcells in urban area[C]//Proceedings of IEEE VTS 53rd Vehicular Technology Conference. Piscataway: IEEE Press, 2002: 333-336.
- [17] WANG Z Y, TAMEH E K, NIX A R. Joint shadowing process in urban peer-to-peer radio channels[J]. IEEE Transactions on Vehicular Technology, 2008, 57(1): 52-64.
- [18] WANG S Q, TUOR T, SALONIDIS T, et al. When edge meets learning: adaptive control for resource-constrained distributed machine learning[C]//Proceedings of IEEE INFOCOM 2018 - IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2018: 63-71.
- [19] WANG S Q, TUOR T, SALONIDIS T, et al. Adaptive federated learning in resource constrained edge computing systems[J]. IEEE Journal on Selected Areas in Communications, 2019, 37(6): 1205-1221.
- [20] AHN S, LEE J, PARK S, et al. Competitive partial computation offloading for maximizing energy efficiency in mobile cloud computing[J]. IEEE Access, 2017, 6: 899-912.
- [21] MAO Y Y, ZHANG J, LETAIEF K B. Dynamic computation offloading for mobile-edge computing with energy harvesting devices[J].

IEEE Journal on Selected Areas in Communications, 2016, 34(12): 3590-3605.

- [22] TRAN N H, BAO W, ZOMAYA A, et al. Federated learning over wireless networks: optimization model design and analysis[C]//Proceedings of IEEE Conference on Computer Communications. Piscataway: IEEE Press, 2019: 1387-1395.
- [23] MA C X, KONEČNÝ J, JAGGI M, et al. Distributed optimization with arbitrary local solvers[J]. Optimization Methods and Software, 2017, 32(4): 813-848.
- [24] KONEČNÝ J, QU Z, RICHTÁRIK P. Semi-stochastic coordinate descent[J]. Optimization Methods and Software, 2017, 32(5): 993-1005.
- [25] ZHANG J Y, CHEN S F, LIN Y, et al. Cell-free massive MIMO: a new next-generation paradigm[J]. IEEE Access, 2019, 7: 99878-99888.



黄赛 (1989-), 男, 河北保定人, 博士, 北京邮电大学副教授、博士生导师, 主要研究方向为基于机器学习的智能信号处理、通用无线信号快速检测与深度识别等。



潘春雨 (1989-), 女, 河南南阳人, 博士, 北京信息科技大学副教授、硕士生导师, 主要研究方向为无蜂窝网络、无人机通信, 资源管理、边缘计算、人工智能等。

[作者简介]



姚媛媛 (1988-), 女, 河南驻马店人, 博士, 北京信息科技大学副教授、硕士生导师, 主要研究方向为无蜂窝大规模 MIMO、智能反射面辅助通信、无人机通信等。



李学华 (1977-), 女, 湖北荆州人, 博士, 北京信息科技大学教授、硕士生导师, 主要研究方向为无线通信物理层关键技术等。



刘忆秋 (1998-), 女, 河南安阳人, 北京信息科技大学硕士生, 主要研究方向为无蜂窝大规模 MIMO、边缘计算、联邦学习等。



袁昕 (1990-), 女, 江苏扬州人, 博士, 澳洲联邦科学与工业研究组织研究科学家, 悉尼科技大学访问学者, 主要研究方向为机器学习和优化及其在无人机网络和智能系统中的应用。